

Partie 1 : Statistique descriptive

Généralités:

Introduction:

La stat. descriptive est une science qui consiste à récolter des données caractères, notés $X, Y, Z \dots$ chiffrées sur des ensembles nombreux ex: X : sexe $\left\{ \begin{array}{l} \rightarrow F \\ \rightarrow M \end{array} \right\}$ Modalités.
 Y : âge.
 Z : couleur des cheveux.


Vocabulaire:

Déf (1): Population ou univers

(pop.): l'ensemble d'étude, notée Ω .

Déf (2): Individu (ind.): un élément de la pop.

Déf (3): la taille de la pop.: le cardinal de la pop = le nbre d'ind. de la pop, noté $|\Omega|$.



$$\Omega = \{ \omega_1, \omega_2, \dots, \omega_n \}$$

$$|\Omega| = n.$$

Déf (4): Échantillon (éch.): sous-ensemble (partie) de la pop. Il est aléatoire si son prélèvement est soumis aux lois du hasard.

Déf (5): Caractère: chaque ind. peut présenter plusieurs caractéristiques appelées $X, Y, Z \dots$

Déf (6): Modalité: spécificité du caractère. ex: caractère $X \left\{ \begin{array}{l} \rightarrow F \\ \rightarrow M \end{array} \right\}$ Modalités.

Déf (7): Nature: un caractère peut être:

- **Qualitatif:**
 - **Ordinal:** les mod. peuvent être classées (ordonnées)
ex: intensité de la douleur.

- **Nominal:** les mod. ne peuvent pas être classées
ex: la couleur des yeux.

- **Quantitatif:** les mod. sont mesurables.

- **Discret ou discontinu:** les mod. prennent des valeurs isolées
ex: nbre d'enfants: 1, 2, 3, 0...

- **Continu:** les mod. prennent des valeurs appartenant à une intervalle de $\mathbb{R}$.
ex: poids.

Notes:

- Tout ce qui peut être mesuré avec un instrument de mesure est continu (ex: poids).

$$\begin{array}{ccc} 44,5 - \varepsilon & 44,5 \text{ kg} & 44,5 + \varepsilon \\ \times & \bullet & \times \end{array}$$

ε : erreur de calcul.

- Un car. quantitatif est aussi appelé variable statistique.

Chapitre 1: Statistiques simples:

On s'intéresse à l'étude d'un seul caractère.

1/ Définitions:

ex 1:

Une enquête effectuée dans un immeuble de 26 logts porte sur le nbre d'écoliers par logt. Les résultats de l'enquête sont les suivants:

0 1 0 5 2 3
0 1 1 1 0 1
2 1 2 3 1 2
3 1 1 3 1 4
2 2

X = nbre d'écoliers / logt.

$\text{Mod.} = \{0, 1, 2, 3, 4, 5\}$.

k = nbre de modalités.

$k = 6$

n = effectif total.

Tableaux statistiques:

i	x_i	n_i	n_{ic}	f_i	f_{ic}	$n_i x_i$	$n_i x_i^2$
1	0	4	4	$\frac{4}{26}$	$\frac{4}{26}$	0	0
2	1	10	14	$\frac{10}{26}$	$\frac{14}{26}$	10	10
3	2	6	20	$\frac{6}{26}$	$\frac{20}{26}$	12	24
4	3	4	24	$\frac{4}{26}$	$\frac{24}{26}$	12	36
5	4	1	25	$\frac{1}{26}$	$\frac{25}{26}$	4	16
6	5	1	26	$\frac{1}{26}$	$\frac{26}{26} = 1$	5	25
Total:		26		1		43	111

$x_i = i^{\text{ème}}$ modalité.

n_i = effectif de la $i^{\text{ème}}$ modalité

n_{ic} = effectif cumulé de la $i^{\text{ème}}$ modalité
 $= n_1 + n_2 + n_3 + \dots + n_i$.

ex: $n_{ic} = n_1$

$n_{2c} = n_1 + n_2$.


f_i = fréquence = $\frac{n_i}{n}$.

$f_{ic} = f_{1c} + f_{2c} + \dots + f_{ic} = \frac{n_{ic}}{n}$.

II/ Regroupement en classes:

On regroupe les données en classes de même amplitude.

Classe = intervalle du type $[a; b[$



$$E = x_{\max} - x_{\min}$$

l = amplitude (largeur de la classe)

k = nombre de classes.

Dans notre exemple: $E = 17,95 - 15,08 = 2,86$

$$l = 0,5$$

$$\text{Si } E = k \times l \Rightarrow k = \frac{E}{l} = \frac{2,86}{0,5} = 5,72$$

on prend: $k = 6$

$[15; 15,50[$ $[15,50; 16[$ $[16; 16,5[$ $[16,5; 17[$

$[17; 17,5[$ $[17,5; 18[$

III/ Représentations graphiques:


A/ Caractères quantitatifs:

1- Caractère discret:

ex: les écoliers.

i/ Diagramme en bâtons:

Effectifs (n_i)




ii/ Polygone des fréquences:

Voici le diagramme en bâtons.

iii/ Courbe cumulative des fréquences

(Fonction de répartition)



Fonction en escaliers, elle est croissante continue à droite, discontinue à gauche.

$$\lim_{x \rightarrow +\infty} f(x) = 1 ; \lim_{x \rightarrow -\infty} f(x) = 0$$

2/ Caractère continu:


ex: le poids de 100 jeunes adolescents

Classes	n_i	f_i	n_{ic}	Centre de classe	y_i	$n_i y_i$	$n_i y_i^2$
$[38; 40[$	11	$11/100$	11	39	-2	-22	44
$[40; 42[$	28	$28/100$	39	41	-1	-28	28
$[42; 44[$	16	$16/100$	55	43	0	0	0
$[44; 46[$	25	$25/100$	80	45	1	25	25
$[46; 48[$	15	$15/100$	95	47	2	30	60
$[48; 50]$	5	$5/100$	100	49	3	15	45

Total: 100


20 202

i/ Histogramme:



ii/ Polygone des fréquences:
voir l'histogramme.

iii/ Courbes cumulative des fréquences:



B/ Caractères qualitatifs:

ex: Répartition des principaux cancers chez les femmes dans la région d'Alger.

- Cancer du sein (30%)
- Cancer de l'appareil digestif (20%)
- Cancer des organes génitaux (20%)
- Cancer de la peau (6%)
- Cancer de la thyroïde (6%)
- Autres (18%).


Diagramme en secteurs circulaires

$$100\% \rightarrow 360^\circ$$


$$x\% \rightarrow \theta$$

$$\theta = \frac{x\% \times 360}{100\%}$$

$$\theta = f_{ic} \cdot 360^\circ$$



Représentation en tuyaux d'orgue:



IV/ Paramètres de position et de

dispersion:

A/ Paramètres de position:

1- Le mode: c'est la valeur la plus fréquente de la série statistique.

"Le mode est une modalité, non pas un effectif."

ex 1: cas discret: les écoliers.

$M_0 = 1$. (eff. max = 10).

ex 2: cas continu: le poids des ados

le mode est le milieu (ou le centre) de la classe modale (celle qui a le plus grand effectif).

$M_0 = 41$. (eff. max = 28).

Une série statistique peut être uni-modale ou pluri-modale.

2- Les quantiles:

Soit la série statistique ordonnée

$$x_1 \leq x_2 \leq \dots \leq x_n$$

ex: les écoliers: 0000 1111111111...

$x_1, x_2, \dots$

3 4 5
... x_{26}

a/ Définition: soit $\alpha \in]0, 1[$. On

appelle "quantile" d'ordre α de la variable statistique x , noté q_α la

valeur numérique telle que le


nombre d'observations inférieures à q_α ou égales soit égal à $n\alpha$.

$$n = 26 \quad \alpha = 0,5 \quad q_{0,5} = x_{14}$$

$$n\alpha = 13$$

N.B.:

$$q_{0,5} = \text{la médiane} = M_e = Q_2 \text{ (quantile)} = q_{0,5}$$



$$Q_1 = q_{0,25} \quad Q_3 = q_{0,75}$$

- Il y a 3 quantiles.

- Il y a 9 déciles.

- Il y a 99 centiles.

- Il y a 999 milliles.


b/ Calcul pratique des quantiles:

i/ caractère discret:

$$q_\alpha = \begin{cases} \frac{x_{n\alpha} + x_{n\alpha+1}}{2} & \text{si } n\alpha \in \mathbb{N} \\ x_{[n\alpha]+1} & \text{si } n\alpha \notin \mathbb{N} \end{cases}$$


$[n\alpha]$: partie
entière de $n\alpha$
 $[12,5] = 12$

ii/ Caractère continu:



Le quantile d'ordre α est l'abscisse du point qui a pour ordonnée $n\alpha$ ou α

$$q_\alpha = l_1 + \frac{l_2 - l_1}{f_2 - f_1} (n\alpha - f_1)$$



$$\frac{f_2 - f_1}{l_2 - l_1} = \frac{n_\alpha - f_1}{q_\alpha - l_1}$$

$$\Rightarrow q_\alpha - l_1 = \frac{l_2 - l_1}{f_2 - f_1} (n_\alpha - f_1)$$

$$q_\alpha = \frac{l_2 - l_1}{f_2 - f_1} (n_\alpha - f_1) + l_1$$

ex: les poids des ados.

$$Q_1 = q_{1/4} \quad n_{1/4} = 100 \left(\frac{1}{4} \right) = 25$$

$$11 < 25 < 39$$

$$40 < Q_1 < 42$$

$$\frac{Q_1 - 40}{25 - 11} = \frac{42 - 40}{39 - 11}$$

$$\Rightarrow Q_1 - 40 = \frac{42 - 40}{39 - 11} (25 - 11)$$

$$Q_1 = 40 + \frac{42 - 40}{39 - 11} (25 - 11)$$

$$Q_1 = 41$$

3- La moyenne arithmétique:

Elle est donnée par:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^k n_i x_i$$

k: nombre de modalités (cas discret)
nombre de classes (cas continu).

x_i : $\rightarrow$ modalité (cas discret)
 $\rightarrow$ centre de classe (cas continu)

n_i : effectif

n : effectif total

ex 1: cas discret (écoliers).

$$\bar{X} = 1,65 \text{ écolier / logt}$$

ex 2: cas continu (le poids des ados)

$$\bar{X} = 43,40 \text{ kg.}$$

B/ Paramètres de dispersion:

1- Variance et écart-type:

a/ Variance:

Elle est donnée par:

$$\text{Var } X = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{X})^2$$

Pour le calcul, on utilise:

$$\text{Var } X = \left(\frac{1}{n} \sum_{i=1}^k n_i x_i^2 \right) - \bar{X}^2$$

b/ Écart-type:

Il est donné par:

$$\sigma_x = \sqrt{\text{Var } X}$$

* Remarque: $\text{Var } X \geq 0$

c/ Changement de variables:

Soit X une variable statistique, et a et b , 2 nbres réels ($\neq 0$).

Soit $Y = aX + b$, alors:

$$\begin{cases} \bar{Y} = a\bar{X} + b \\ \text{Var } Y = a^2 \text{Var } X \end{cases}$$

ex 1: les écoliers.

$$\text{Var } X = \left[\frac{1}{26} (111) \right] - 1,65^2 = 1,55$$

ex 2: le poids des ados.

$$\text{Var } X = 7,92$$

On pose: $X = aY + b$.

$$Y = \frac{X - b}{a}$$

b = centre de classe médian ou modal

$$b = 43$$

a = amplitude des classes

$$a = 2$$

$$\text{Var } Y = \frac{202}{100} - (0,2)^2 = 1,98.$$

$$\text{Var } X = a^2 \text{Var } Y = 2^2(1,98) = 7,92$$

2- Coefficient de variation:

On le note par CV, il s'écrit:

$$CV_x = \frac{s_x}{\bar{X}}$$

ex 1: les écoliers: $\bar{X} = 1,65$

$$s_x = \sqrt{\text{Var } X} = \sqrt{1,55} = 1,245$$

$$CV_1 = 0,75.$$

ex 2: les ados: $\bar{X} = 43,4$.


$$s_x = \sqrt{\text{Var } X} = \sqrt{7,92} = 2,81$$

$$CV_2 = 0,065.$$

$$CV_1 > CV_2$$

$\Rightarrow$ Série 1 est plus dispersée
que Série 2.

3- Intervalle inter-quartile:



C'est l'intervalle qui contient 50%
des observations, qui se situent au
centre de la série statistique, sym-
étriquement par rapport à la médiane.

$$(Q_3 - Q_1) = \text{écart inter-quartile.}$$